02 | 爬虫的内卷和黑化：我们变得不正经啦

2022-01-21 DS Hunter

《反爬虫兵法演绎20讲》 课程介绍 >

讲述：DS Hunter

时长 21:02 大小 19.27M

你好，我是 DS Hunter。

在上节课里，我们讲了上古田园时代和春秋时代的爬虫发展，这个时候爬虫还是有礼节的。但是到了后面的战国时期，就彻底礼崩乐坏，慢慢变得无恶不作了。爬虫也从一门技术，变成了一门生意。

因此，面临这种超出想象的变化，在激烈的对抗间，我们的各类招式也层出不穷。这节课，我们就聚焦到战国时代，我会给你讲解几个在爬虫和反爬虫的斗争期间，双方常用到的招式，像爬虫方常用的接口定制化爬虫、机器人工双校验，以及反爬虫方常用的数据污染策略和字体文件反爬。

这些招式会按照相互克制的顺序展开。我们一块来看看，在商业的高度内卷下，爬虫变成了什么样子。

黑化的爬虫和反爬虫的对抗

在战国时期爬虫和反爬虫的对抗中，服务器的压力已经不再是最大的问题了。

服务器是固定成本，而且大厂通常十分冗余，或者说浪费。即使有部分爬虫来，也不会造成什么影响。这个时候大家更关注的是：**如何在商业上获胜。**商业竞争逐渐激烈，面对这样的环境，爬虫越来越接口定制化。

爬虫第一招：接口定制化爬虫

定制化，简单地说就是只拉接口，不拖泥带水地进行没用的请求。我给你画了一个接口定制化爬虫产生的过程图，你可以参考一下。

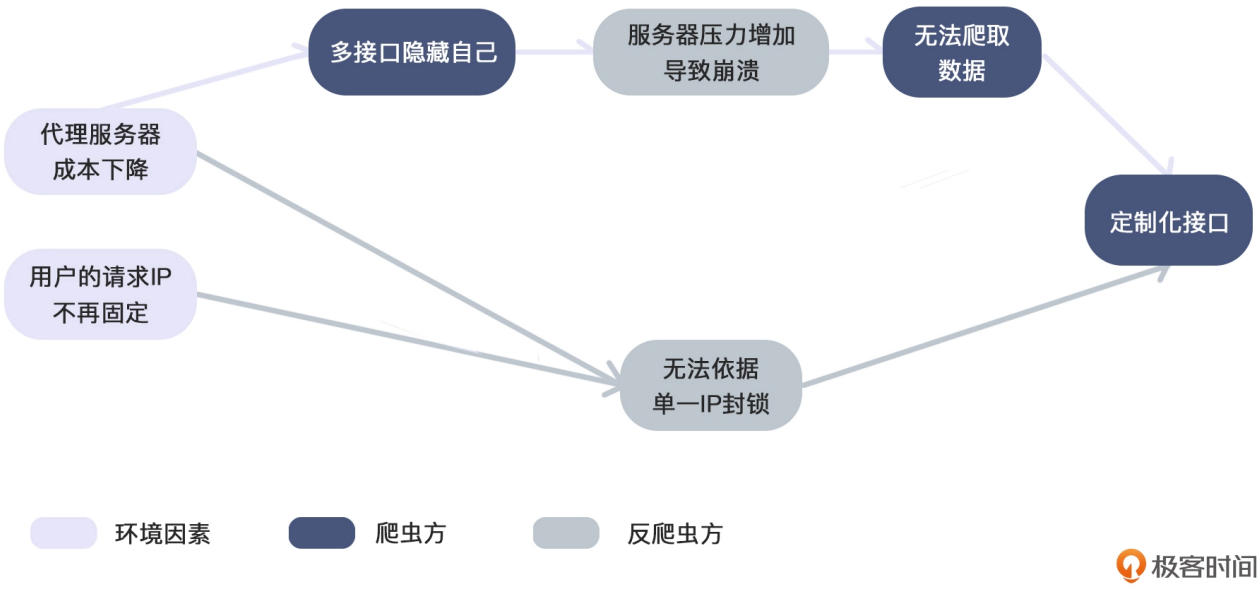

接口定制化爬虫产生过程

最早，爬虫还没有开始接口定制化，而反爬虫会根据 IP 以及访问频率进行简单的封锁。举例来说，假设一个 IP 地址只访问你的价格接口，不访问你的其余接口，也不访问静态页面，那么，超过一定的阈值，这个 IP 地址就会被拉黑。

时间长了，爬虫就会选择多爬一点没用的数据来伪装自己，把想爬的接口隐藏在自己的请求中。但是随着代理服务器成本下降以及大环境的改变，这种方法就不再适用了。

这里还是用价格战来给你举例：如果反爬虫服务器针对一个 IP 拉黑的阈值是访问 10 次价格接口，那么爬虫方如果想发起 10000 次的接口请求，只需要使用 1000 个代理。

我们先说第一条走向定制化的路，**代理服务器成本下降。**成本下降，突破 IP 封锁就从一个技术问题变成了 ROI（return on investment，投资回报率）的问题。而能用钱解决的，就不再是问题了。毕竟只要增加代理服务器，**增加接口隐藏自己，**总是可以爬取到需要的数据的。但是，这样会给对方的服务器带来更大的压力，对方崩了，自己也得不到数据。

而第二条路，不仅和代理服务器成本下降有关，更有大环境影响的因素。随着移动互联网的普及，**用户的请求 IP 不再是固定的，**同一个 IP 上一秒还归路人甲使用，下一秒可能就给路人乙了。反爬虫方也不太敢继续依据固定 IP 的访问频率封锁了。

所以，在这个时候，爬虫方开始大胆使用接口定制化的爬虫，而不再使用通用爬虫。不过后面这个还会再反转。这个在结尾我们会再谈。

反爬第一式：数据混淆策略

爬虫和反爬虫打了一段时间后，反爬虫的业务方就提出了新的要求：就算被爬取了，也要让被爬取的数据产生价值。这里我们创设一个情境来说明。

例如，AB 两家公司，A 的商业策略是，优先保证盈利，保护股东利益。而 B 的商业策略是，尽可能低价占领市场。那么当他们互相爬取对方的时候，反爬团队都会如何处理呢？这里我为你准备了一个表格，你可以在学习的时候思考一下，AB 两家公司双方都在想些什么。

	爬虫方（B）		反爬虫方（A）
待办 1		反击 1	
……		……	

极客时间

博弈过程中双方的决策过程

A 公司的日常定价必然是高价优质服务，B 公司的日常定价必然是低价低质服务，甚至无服务。

这个时候，B 公司的爬虫如果来爬 A 公司，A 公司的业务会如何考虑问题？

1. 我们公司的商品卖 100，他们一般是卖 99；
2. 对方爬虫抓到我们的价格，一定会在定价的时候减价售卖；
3. 基于这个考虑，我们做一个提价吧，就告诉他们的爬虫，我们卖 120；
4. 对方拿到 120 的价格，一定会降价到比我们低的价格卖，可能就是 119。这样，我们的 100 还是有价格优势的。
   好了，推测先到这里，我给你总结了一张爬虫方 B 爬取 A 的思路与做法表格：

	爬虫方-B	反爬虫方-A
明确自身商业特性	提供低价低质服务（99元）	提供高价优质服务（100元）
（被）爬取的目标数据	价格	价格
B：爬取的目的 A：被爬取后希望展示的信息	比较价格、调整价格	展示虚高的价格
博弈的目的	比反爬虫方A便宜 低价占领市场	比爬虫方B便宜 盈利且提供优质服务
（爬虫B）获取的价格 （反爬虫A）给出的价格	120元	120元
客户端最终价格	119元	100元
博弈结果	根据虚高价格适当涨价，导致价格过高	提供优质服务的同时建立价格优势，盈利更多

极客时间

博弈过程中双方的决策-1

爬虫方 B 公司找反爬虫方 A 公司爬取数据的情况说完，我们来看看反过来的情况，也就是说，现在博弈中的两个角色变成了爬虫方 A 和反爬虫方 B。

实际上，A 公司的爬虫在爬取 B 公司的时候，B 公司的业务必然也是反向思考的。也就是说，B 给的价格必然是比实际价格还低一点的（你也可以列表试试推理这种情况）。

这里你也可以参考一下我给你提供的爬虫方 A 爬取反爬虫方 B 的博弈过程：

	反爬虫方-B	爬虫方-A
明确自身商业特性	提供低价低质服务 （99元）	提供高价优质服务 （100元）
（被）爬取的目标数据	价格	价格
A：爬取的目的 B：被爬取后希望展示的信息	展示过低价格	比较价格，调整价格
博弈的目的	情况1：逼迫爬虫方A大幅降价放弃盈利 情况2：不更改价格保持自身价格优势	保留服务优势 争取价格优势
（爬虫A）获取的价格 （反爬虫B）给出的价格	80元	80元
客户端最终价格	99元	情况1：80元 情况2：100元
博弈结果	情况1：没有价格优势 但爬虫方亏本 情况2：依旧存在价格优势	情况1：无法盈利甚至亏本 情况2：盈利但没有价格优势

极客时间

博弈过程中双方的决策-2

可以看到，B 会给出较低的价格（例如表格中的 80），有本事你就跟进，我就不信你敢放弃股东利益，降价到这个程度。

这样，同样的商品，本来售价 100，结果 A 告诉 B，我卖 120。B 告诉 A，我卖 80。爬虫就像一个间谍，拿到数据不可怕，可怕的是拿到错误的数据，给出错误的商业决策。

你看，这个时候，反爬虫方并非专注于技术手段的提升，而是开始利用起了被爬取数据这件事。就算被爬取，也要让这个被对方抓到的数据产生价值。通过给对方错误的信息，使对方产生错误的判断，并在这条路上越走越远。这手段，多不正经。不过也不用觉得复杂，刚刚我们填好的表格，就是这场反爬战的思路。

爬虫第二招：机器人工双校验

“机器人工双校验”这个招数，你可以把它看成一个动作链条，在这个链条里的爬虫会使出各种手段与反爬虫方斗争，获取想要的数据。这里的“不正经”成分达到了巅峰，在爬虫与反爬虫的博弈之间，充满了尔虞我诈。

下面是一张机器人工双校验的动作链条示意图（空格处待填写）。接下来我们就一起让整个动作链条完整起来——置身于战场，才能了解隐藏在战争背后的每一个想法。在整个动作链条里，逻辑对抗无处不在，那直接就开始吧。

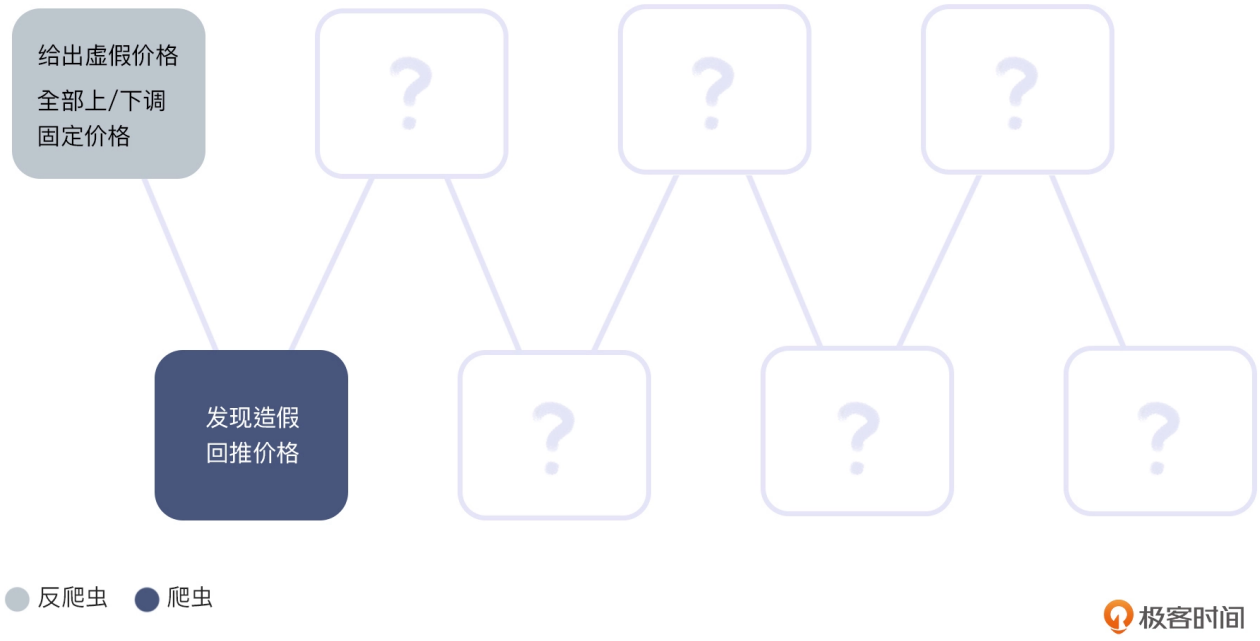

机器人工双校验动作链条示意图-1

我们现在来看一个新的战况：爬虫方 B 公司，在爬取走高端路线的 A 公司的价格的时候，每次都拿到 80。也就是说，反爬虫方 A 选择用不同的价格迷惑对方。时间长了，爬虫方 B 公司就会发现不对了：80 是一个亏本价格，不符合 A 走高端路线的风格。稍加分析就会发现：价格被掺假了，下降了 20%。

面对刚刚说到的反爬方 A 的数据混淆策略，爬虫不得不做出改变。那么这个时候爬虫的第一个办法就出现了：既然所有的价格都下降了 20%，那么如果我真的无法突破反爬虫系统，就去抓错误的价格，然后再加回来，不就行了吗？我干嘛死磕对面的反爬虫系统呢？没错，它们选择了**不在技术上交锋，而是用自己的推断得出正确的价格信息。**

现在看来，这样奇葩的做法可能有些不可思议。但是在历史上，这是真实存在的。很多反爬虫系统都有过这样的黑历史，那就是：**防住了，但是等于没有防住。**

随机虚假价格和两次请求

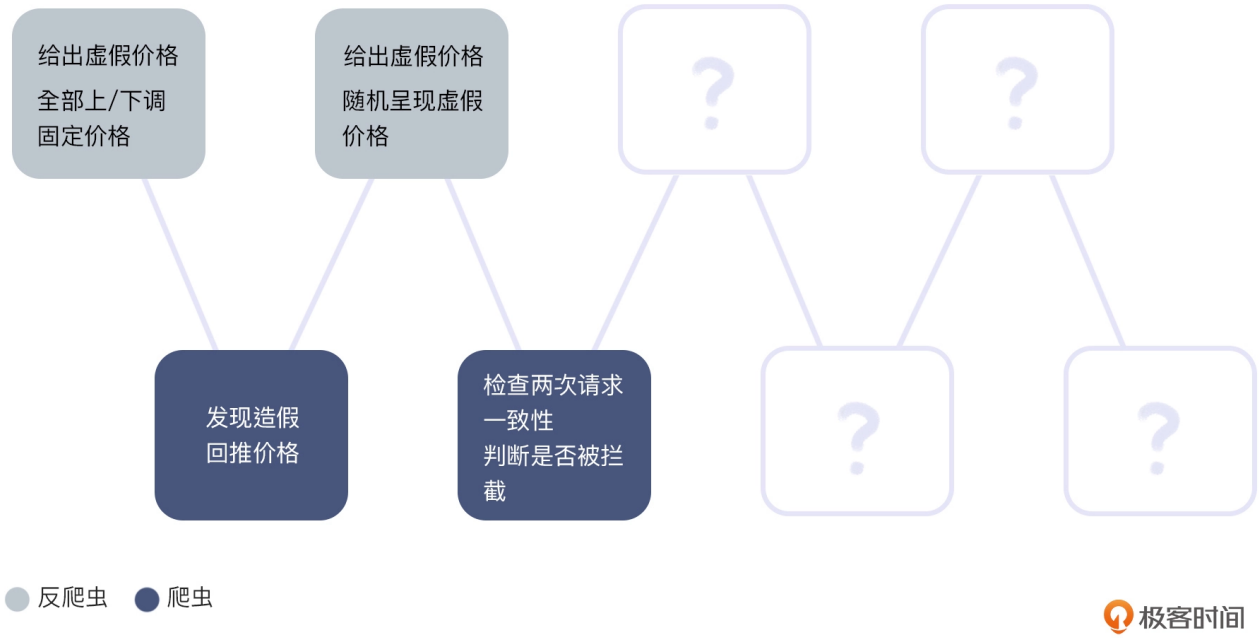

机器人工双校验动作链条示意图-2

另一方面，面对爬虫的第一个方法——回推价格，反爬方开始了将**价格的变更幅度做成随机的策略。**这次展示 80 的价格，下次展示 75 的价格，每次都不一样，这样就没办法反推回来了。

为了应对随机变化的价格，爬虫方开始了我们的第一个机器校验方法：**进行两次请求。**这样，通过检查价格是否一致，就可以轻松校验自己的爬虫系统是否被拦截了。例如，第一次请求一个商品的时候，价格是 80，相同的参数再请求一次，价格又变成了 75，前后时间可能只差 1 秒，但是 1 秒内商品变价的概率并不高——那就可以证明，自己被拦截了。

好了，大致的博弈先告一段落。你可能已经迫不及待开始预测爬虫方下一步的动作了：这个时候是不是就可以停掉爬虫，慢慢调试自己的代码，等每次价格都正确的时候再爬呢？毕竟爬取也是需要消耗资源的。停下来，能有效节约一部分成本，同时，也可以降低对方的服务器资源消耗，避免爬虫把对方爬崩之后两败俱伤。

如果你的回答是：Yes！那么恭喜你，你被反爬虫坑了！因为如果反爬虫方发现你的策略是，错一次就停下来重爬，那么他会无脑给一些低概率的错误价格。

举个例子，对方根本没有发现你的爬虫。但是，反爬虫系统用一个极低的概率，随机给一次错误价格。我们假设，反爬虫方给一次错误价格的概率设置为万分之一。那么，线上用户被影响的概率是极低的，并且影响了也不容易被发现。但是你的爬虫运行一万次，算过

来可能就碰到一次错误的价格。如果就这样停下爬虫来调试，一定是一无所获。毕竟，这只是随机事件啊！所以你本着替双方着想的初衷做了这个熔断，但是结果却卷输了自己。实在是太冤枉了。

看看，是不是充满了不正经的尔虞我诈。

部分随机价格和有意抓取

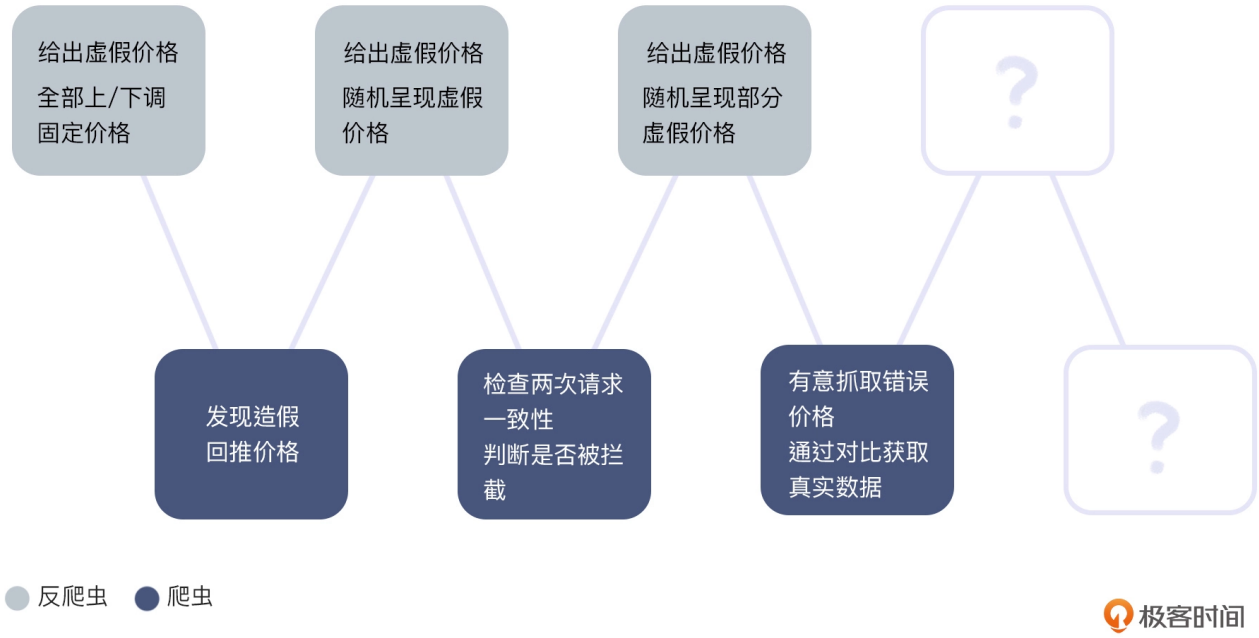

机器人工双校验动作链条示意图-3

回到爬虫方两次请求的进攻方式，反爬方选择**让价格不随机。但是不随机不就回到开头的状态了吗？这个时候我们可以选择一个部分随机**的解法。

简单地说就是，同一个商品，相同时间段内，价格随机幅度不变。例如商品 A，价格是 100 元。当前一小时内你算出一个随机值，例如是 13%，那么 A 商品在这一小时内，将一直提价 13%。而另一个商品 B 在这一小时的提价幅度可能是 15%。这样既实现了价格不确定，又避免了被相同请求验算。一举两得。因为相同的请求，必然得到相同的结果。

那么，爬虫方是否还有办法检测自己是否运行正常呢？

有的。答案就是：有意抓取错误价格。

其实道理很简单，相同的数据，相同的时间内价格是一样的。那么，哪个价格是真的我不好找，但哪个价格是假的，我还是很容易找的吧？我有意撞一下反爬不就行了？有意告诉反爬系统，我就是爬虫，快给我假价格。拿到假价格之后，你再进行一次正常的请求，看下是否一致不就行了吗？

策略针对和人工校验

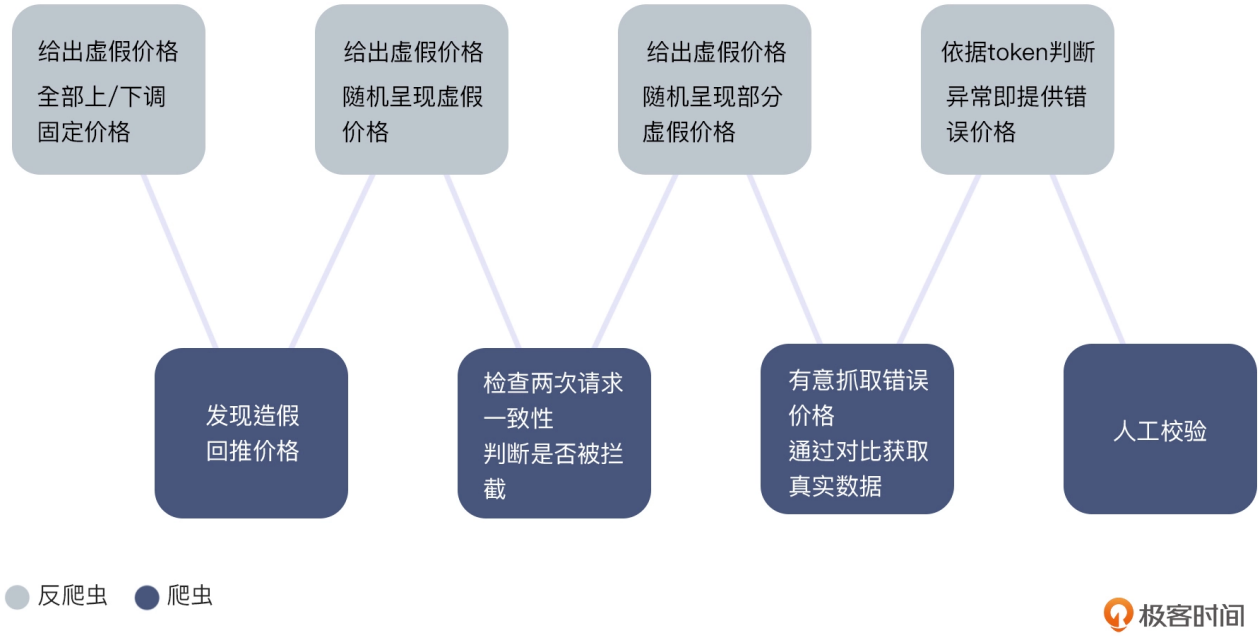

机器人工双校验动作链条示意图-4

那么现在再绕回来，假设你是反爬方，对方这样检查自己的爬虫是否正常，你如何处理？

答案其实也是显然的，你只需要针对不同的策略返回不同的假价格就行了。举个例子，你的反爬可能依赖一个 Token。对方可能用 Token 缺失的请求来校验。这个时候，你给出 13% 的提价。当 Token 存在，但是 Token 错误的时候，你给出 16% 的提价。而 Token 长度不正确，你给出 15% 的提价。或者 Token 奇偶校验错误，你给出 12% 的提价，价格复杂多变起来，这个问题就轻松解决了。

那么爬虫方面对这个办法是不是无能为力了呢？也不是的！

这个时候，爬虫方就可以加入人工校验了。因为爬虫方只需要确认自己是否运行正常，那么只要有一个校验错误，就意味着自己不正常，所以这个成本还是很低的，只需要在爬取

到的数据中抽样即可。也就是说，只要用人工来进行抽样检测，就可以在概率上检测自己运行是否正常。

从另一个角度来说，对方针对爬虫给出了各种花式的价格，他能保证 100% 命中爬虫，而不命中正常人吗？不能。这种价格混淆俗称“下毒”。那么，就像狼人杀里面的女巫一样，你能保证自己不毒到平民吗？不可能的，概率永远是存在的。那么你就可以通过众包的方式让真实的用户去访问，通过比对看到的价格，就可以确认自己是否运行正常。当然，这个过程中也必然会有真实用户被误伤。

也许你会很好奇：误伤了会怎么样呢？

不同的用户看到不同的价格，去投诉竞对大数据杀熟，让他领导开除他啊！

如果你刚刚真的想问这个问题，我还是很高兴的，这证明你还保持着纯真和善良。毕竟从刚刚一来一回的分析中你也肯定感受到了——反爬是一个很腐蚀心智的事情。而你，还是关心真实的用户的。

反爬第二式：字体文件反爬

是不是受不了了？快从刚才说的那些腐蚀心智的斗争中拉回来，回到一些正经的话题上来。这里的反爬手段，就没有那么的尔虞我诈了。

为了防止真正的用户受到反爬虫的误伤，通常网上的一些教程一定会教你“字体文件反爬”，也就是说，让展示出的价格使用自定义字体来实现反爬虫。简单地说，你可以创建一个自定义字体。因为字体可以定义文字书写方式，你完全可以在该字体下，将数字打乱。例如“1”显示成“3”，“3”显示成“7”，“7”显示成“5”等等。这样，你下发的价格其实是错误的价格。但是真正的用户通过这个字体文件加载之后，会被 mapping（映射），显示成为一个正确的价格，不影响使用。

网络上对这个办法赞赏不已，但是我告诉你：这个办法虽然酷炫，但它其实是一个下下策。

为什么？

第一个，**因为时间成本。**你想一下，如果你做了这个字体文件，你需要花费多少时间？一天？这算效率高的了吧？但是对方发现之后，mapping 回来需要多久？

五分钟。

你拿一天的时间拼人家五分钟，这划算吗？

我在开篇就提到了，反爬虫拼的就是资源。而资源包括机器和人力资源的综合。其中，机器资源成本越来越低，但是人力成本，却随着程序员的工资水涨船高。因此在人力资源上拼亏了，极大可能上，会输掉整个博弈。

除了不划算这个问题，第二点，就是**依旧会误伤用户。**如果字体文件加载失败，真实的价格是不是就被迫用默认字体渲染？默认字体可没这个 mapping。所以，一旦字体文件加载失败，这个办法依旧会对普通用户造成伤害，并且伤害极大。而对爬虫，只会造成 5 分钟的困扰。这真的划算吗？

第三点，如果对方有意屏蔽你的字体文件，然后制造一个网络不好**加载失败**导致价格错乱的假象，接着导致在 iPhone 上价格变高了，对方截图，然后再截一个正常的 Android 系统的价格。两张图放到一起比对，iPhone 价格高，Android 价格低，看人下菜碟石锤了。这个投诉估计就够你处理半个月了。所以，这对你，也就是反爬方，也是一种伤害。

最后，如果非用这个办法不可，请一定要记住：字体文件并不大，请直接 inline 到 HTML 里，这样，只要 HTML 加载成功，字体文件不可能失败，两者是同进同退的，不用担心上面提到的价格错乱问题。而上面说的对普通用户的误伤甚至是对你的伤害，就不会存在。不过更好的选择是，**不使用这个看起来酷炫实际上无意义的小技巧。**

小结

好了，我们的爬虫反爬虫内卷的历史就这样告一段落。

当然，这里还没有讨论验证码和浏览器爬虫，以及针对浏览器爬虫的对策。这个我们会在下一讲里讨论。尤其是爬虫方可以用浏览器爬虫秒杀大部分的反爬机制，反爬被逼无奈放大招的时候，会让人忍不住怀疑人性到底可以多黑暗。

单看今天讲的内卷历史，确实你来我往，尔虞我诈，变得越来越“不正经”。

首先，接口定制化爬虫，其实就是只拉接口请求想要的数据；而针对这样的爬虫，反爬虫工程师开始了数据混淆策略。我们姑且把他们归为第一轮战争。也就是从这一轮开始，爬虫与反爬虫的斗争开始了对业务的影响。

之后爬虫方卷土重来，为了校验自己是否正常运行，开始机器人工双校验的方法。你可以把这个方法理解为一个链条，里面的每一个动作都是为了验证爬取到的数据是否是真实的；而反爬也不甘示弱，开始字体文件反爬。而这一轮的斗争，开始误伤到普通用户。

在你一招我一式的战争中，还有一些“大招”，它们不一定多高效，但适用性强。类似反爬方的验证码和爬虫的浏览器模拟这两种方法，就是万能的。不过，他们也有缺点。验证码误伤率高，浏览器模拟效率低。或者你可以理解为，伤敌一千，自损八百。

其实，爬虫和反爬虫一直以来是**矛与盾的关系，彼此互相克制。**最终总结下来如下图：

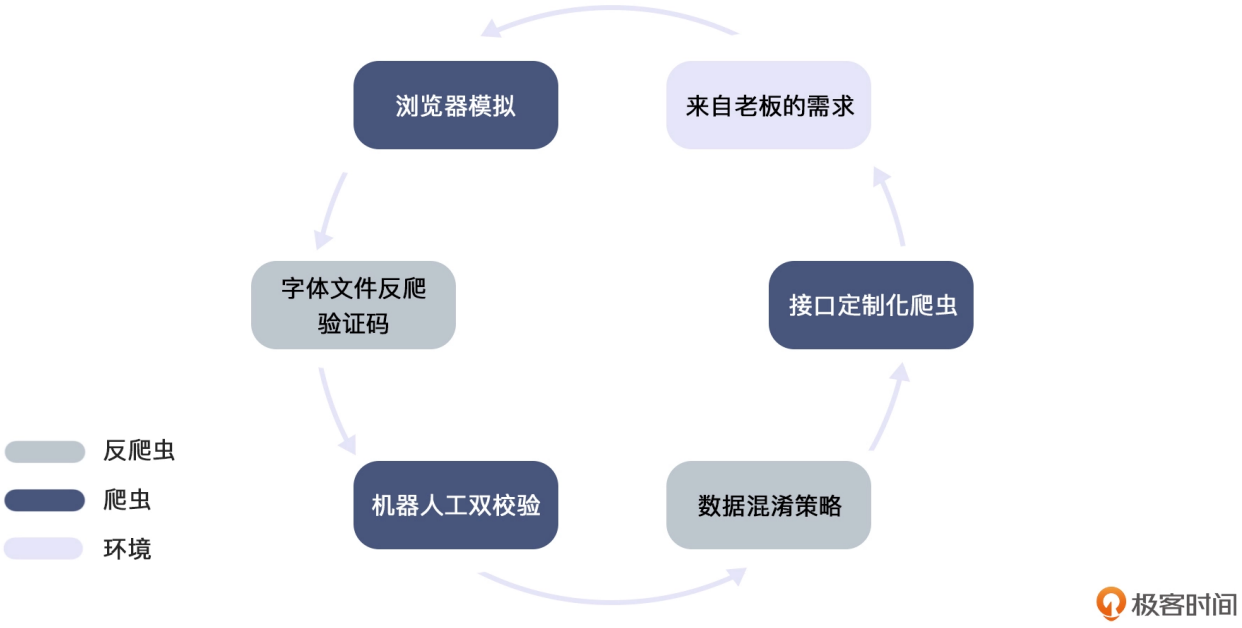

总体看起来，挑事的主要是爬虫，反爬主要是被动防守。这个世界好人难做啊。

那么反爬虫方就会思考了：好人难做，我是好人，是不是就意味着我难做呢？如果这个问题没办法解决，是不是可以反向思考呢？

比如，我也不做好人了？

思考题

好了，这一节课就告一段落了。爬虫反爬虫的不断反转，的确是个很内卷的事情，但这样的内卷又毫无意义——它并不创造价值。那么我们轻松一下，我给你留了三个思考题，你可以任选一个进行作答。

1. 刚刚提到的字体反爬虫虽然酷炫但得不偿失，那么你还知道什么别的酷炫但得不偿失的爬虫反爬虫技巧吗？
2. 数据混淆策略里提到了大量的勾心斗角。那你觉得怎么样才能避免自己多想了一步，导致“聪明反被聪明误”呢？
3. 我们多次提到，技术问题转为 ROI 问题的事情。那么，你在研发中碰到过类似的事情吗？你是如何选择的呢？

期待你在评论区的分享，我会及时回复。反爬无定式，我们一起探索。

极客时间

古神藏于苦海内，心魔生在方寸间。

反爬虫兵法演绎 20 讲

DS Hunter / 反爬虫专家，前某公司研发总监

识别二维码
免费试读

分享给需要的人，Ta订阅超级会员，你将得 50 元

Ta单独订阅本课程，你将得 20 元

生成海报并分享

赞 1 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 01 | 爬虫需求的诞生：我们是正经的软件工程师

精选留言 (1)

写留言

程序员二师兄

2022-01-21

回答一下第一题：别的酷炫但得不偿失的爬虫反爬虫技巧。

不知道接口数据加密算不算：

1、前端发起请求时，在header中使用签名生成的加密参数，由后端进行校验。...

展开

作者回复: 这个其实还好，而且算通用做法了。前端加密不是用于拦住爬虫，而是为了拖死爬虫。这个后面会讲。前端加密做的好，还是可以让对方付出大量代价的。当然的确有些自以为是的脚本，会反倒拖垮自己。比如引发兼容问题。就真的得不偿失了。